



# **Oferta eléctrica a cliente industrial Fijación de prima en una oferta a precio fijo**

Alexandre GOOTJES

Director del proyecto: Fernando González

Tutor en la universidad: Ignacio Cascos Fernández



**Universidad Carlos III de Madrid**



# Agradecimientos

A todos los que han estado a mi lado durante esos meses.

A los colegas del departamento Marketing Sales de Madrid, sin los cuales nada de eso se hubiera podido cumplir.

A mi tutor, Fernando González, por su confianza y su apoyo.

A mi tutor, Ignacio Cascos Fernández, por su ayuda y su disponibilidad.

A Gerónimo Lazareca, por su ayuda en la parte de programación.

A Miguel Terrón, por su presencia en momentos críticos.

A Álvaro Garrido, por su apoyo logístico a lo largo de esos meses.

A Luisa Del Ama, por sus sugerencias estéticas.

A mi familia y a todos mis amigos y amigas.



# Índice

<b>Agradecimientos</b>	<b>1</b>
<b>Introducción y Objetivos</b>	<b>7</b>
1. Introducción	7
2. Objetivos	7
<b>I Mercado Eléctrico</b>	<b>8</b>
1. Funcionamiento	8
1.1. Liberalización del mercado . . . . .	8
1.2. Cadena de valor del Sector eléctrico . . . . .	8
1.3. Agentes del mercado . . . . .	9
1.3.1. Operador del Mercado . . . . .	9
1.3.2. Operador del Sistema . . . . .	9
1.3.3. Órgano Regulador . . . . .	10
2. Conceptos de mercado y conceptos regulados	10
2.1. Componentes del precio eléctrico . . . . .	10
2.2. Conceptos regulados . . . . .	11
2.2.1. Pagos por capacidad . . . . .	11
2.2.2. Pérdidas . . . . .	11
2.2.3. Tasa Local . . . . .	11
2.2.4. Tasa OMIE . . . . .	12
2.2.5. Tarifa de acceso . . . . .	12
2.3. Los mercados . . . . .	12
2.3.1. Los mercados SPOT . . . . .	12
2.3.1.a. Mercado diario . . . . .	12
2.3.1.b. Mercados Intradiarios . . . . .	13
2.3.2. Mercado de Futuro . . . . .	13
2.3.2.a. Función . . . . .	13
2.3.2.b. Los mercados organizados: OMIP	14
2.3.2.c. Los mercados OTC . . . . .	14
2.3.2.d. Los productos ofertados . . . . .	15
2.3.3. Mercado de Ajustes . . . . .	16

<b>II</b>	<b>Comercialización eléctrica</b>	<b>17</b>
<b>1.</b>	<b>Comercialización y compartición del riesgo</b>	<b>17</b>
1.1.	Riesgo comercializadora y riesgo cliente . . . . .	17
1.2.	Producto PASS-THROUGH . . . . .	17
1.3.	Producto SEMI PASS-THROUGH . . . . .	19
1.4.	Producto PASS-POOL . . . . .	19
1.5.	Producto PRECIO FIJO . . . . .	19
<b>2.</b>	<b>La cobertura y la limitación del riesgo</b>	<b>19</b>
2.1.	Cobertura en Base o Cobertura en Pico. . . . .	20
2.2.	Perfil de consumo cliente y prima de riesgo . . . . .	20
<b>3.</b>	<b>La determinación de la prima de riesgo</b>	<b>21</b>
<b>III</b>	<b>Fundamentos teóricos</b>	<b>23</b>
<b>1.</b>	<b>Concepto de serie temporal</b>	<b>23</b>
1.1.	¿Qué es una serie temporal? . . . . .	23
1.2.	Principales objetivos . . . . .	23
1.3.	Procedimiento . . . . .	24
1.3.1.	Objetivo . . . . .	24
1.3.2.	Resultado . . . . .	24
<b>2.</b>	<b>Definición</b>	<b>24</b>
2.1.	Estacionariedad . . . . .	24
2.1.1.	Definición . . . . .	24
2.1.2.	DFA . . . . .	25
2.1.3.	Phillips-Perron . . . . .	25
2.2.	Ruido Blanco . . . . .	26
2.2.1.	Definición . . . . .	26
2.2.2.	Ljung-Box . . . . .	26
2.3.	ACF y PACF . . . . .	26
<b>3.</b>	<b>Procesos SARIMA</b>	<b>27</b>
3.1.	Procesos ARMA . . . . .	27
3.1.1.	Definición . . . . .	27
3.1.2.	Identificación de los órdenes $p$ y $q$ del modelo. . . . .	28
3.1.3.	Validación de modelo . . . . .	28
3.1.4.	Método de selección . . . . .	28
3.2.	Generalización . . . . .	29
3.2.1.	Definición . . . . .	29

3.2.2.	Principios de identificación . . . . .	30
<b>4.</b>	<b>Procesos GARCH</b>	<b>30</b>
4.1.	Contexto . . . . .	30
4.2.	Definición . . . . .	31
4.3.	Testar la presencia de un efecto GARCH en el residuo	31
4.4.	Validez de un modelo GARCH . . . . .	32
<b>5.</b>	<b>Bootstrap</b>	<b>32</b>
<b>6.</b>	<b>Software</b>	<b>32</b>
6.1.	R . . . . .	32
6.2.	L <sup>A</sup> T <sub>E</sub> X . . . . .	33
6.3.	Powerpoint . . . . .	33
<b>IV</b>	<b>Aplicación: Determinación de la prima de riesgo</b>	<b>35</b>
<b>1.</b>	<b>Planteamiento</b>	<b>35</b>
1.1.	Estrategia . . . . .	35
1.2.	Simplificaciones . . . . .	35
1.3.	Datos . . . . .	36
1.4.	Método . . . . .	36
<b>2.</b>	<b>Determinación del modelo</b>	<b>37</b>
2.1.	Método . . . . .	37
2.2.	Serie $Y_t$ . . . . .	37
2.2.1.	Objetivo . . . . .	37
2.2.2.	Modelización . . . . .	38
2.2.3.	Resultados . . . . .	38
2.3.	Serie $D_t$ . . . . .	38
2.3.1.	Objetivo . . . . .	38
2.3.2.	Normalidad . . . . .	38
2.3.3.	Hipótesis . . . . .	39
2.3.4.	Modelización . . . . .	41
2.3.5.	Validación . . . . .	43
2.3.5.a.	Normalidad . . . . .	43
2.3.5.b.	Ruido blanco . . . . .	44
2.3.6.	Transformación . . . . .	44
2.4.	Series $H_{i,t}$ . . . . .	45
2.4.1.	Transformación . . . . .	46
2.4.2.	Hipótesis . . . . .	46



2.4.3.	Modelización . . . . .	47
2.4.4.	Validación . . . . .	49
2.4.4.a.	Normalidad . . . . .	49
2.4.4.b.	Ruido Blanco . . . . .	50
2.5.	Modelización GARCH de los residuos . . . . .	51
2.5.1.	Modelización . . . . .	52
2.6.	Modelo Completo . . . . .	53
<b>3.</b>	<b>Simulaciones</b>	<b>55</b>
3.1.	Serie $Y_t$ . . . . .	55
3.2.	Bootstrap . . . . .	56
3.3.	Número de simulación . . . . .	57
3.4.	Resultados . . . . .	57
<b>4.</b>	<b>Cálculo de cobertura</b>	<b>59</b>
4.1.	Planteamiento del problema . . . . .	59
4.2.	Resultados . . . . .	60
4.3.	Back-Testing 2012 . . . . .	61
<b>5.</b>	<b>Determinación de la prima de riesgo</b>	<b>62</b>
5.1.	Resultados . . . . .	62
5.2.	Back-Testing 2012 . . . . .	64
<b>6.</b>	<b>Conclusión</b>	<b>65</b>
6.1.	La calidad de la previsión . . . . .	65
6.2.	Críticas . . . . .	66
6.3.	Perspectivas de futuras mejoras . . . . .	67
6.4.	Conclusión . . . . .	67
<b>V</b>	<b>Conclusión</b>	<b>69</b>
<b>1.</b>	<b>Objetivos del proyecto</b>	<b>69</b>
<b>2.</b>	<b>Objetivos personales</b>	<b>70</b>
<b>A.</b>	<b>Anexo</b>	<b>73</b>

# Introducción y Objetivos

## 1. Introducción

Durante los ocho últimos meses, he realizado una práctica en GDF-SUEZ, una de las empresas más grandes del sector de la energía en el mundo, tanto a nivel de presencia mundial e integración dentro del sector, como de capitalización y de la producción hasta el suministro. Durante el periodo de mi proyecto, fui incorporado al departamento de Marketing & Sales en el equipo de análisis cuantitativo de "Pricing". Este equipo es el encargado de la emisión de las ofertas a destino de los clientes industriales, fijando los precios y evaluando los riesgos asociados. Es el servicio de apoyo a los comerciales que proponen en un último paso las soluciones desarrolladas por parte de sus analistas. Dentro de este equipo, realicé varias tareas, una de las cuales ha sido la que constituye el cuerpo de este trabajo, es decir, el diseño de un método cuantitativo para la evaluación de las primas de riesgo asociadas a la fijación de un precio fijo.

## 2. Objetivos

Mi objetivo primordial ha sido la elaboración de un proceso para la fijación de un precio fijo en el contexto tan peculiar como es el de la electricidad. En base a ese objetivo principal, se proponen los siguientes objetivos parciales:

- Conocer y describir el funcionamiento del mercado eléctrico.
- Conocer y describir los productos que se ofrecen al mercado.
- Conocer y describir los riesgos asociados a cada producto.
- Diseñar una solución específica por el producto Precio Fijo .

## Parte I

# Mercado Eléctrico

## 1. Funcionamiento

### 1.1. Liberalización del mercado

España, como la mayoría de los países en Europa, ha conocido un cambio profundo en el funcionamiento de su mercado eléctrico a lo largo del siglo pasado con la adopción, poco a poco, de un sistema liberalizado.

Empieza en los años 50 con los primeros Reglamentos de verificaciones eléctricas Tarifa Tope Unificadas 4 (1954) cuando aún había estructura integrada de generación, transporte, distribución y comercialización. Continúa a lo largo de los años 60 una serie de medidas y leyes en las que se introducen los conceptos de regulación, mercado organizado u operador del sistema. Con ello se permite a cada uno que presenta los requisitos establecidos por ley, el poder participar de manera igual a dicho mercado. La liberalización a 100 % del mercado fue logrado a partir del 1 de Enero de 2003.

Esta regulación permite normalizar los intercambios y, a través de sus actores “institucionales”, gestionar, controlar y dirigir las operaciones para asegurar un funcionamiento óptimo. La liberalización supone de esta manera una mayor competencia dentro del mercado.

### 1.2. Cadena de valor del Sector eléctrico

Uno de los requisitos para lograr esta liberalización ha sido la obligación para las empresas de separar lealmente sus actividades en entidades distintas que son la generación, el transporte, la distribución y la comercialización.

- La generación: consiste en la producción de energía eléctrica a partir de otras formas de energía. Como la energía no puede almacenarse, obliga a disponer de capacidades de producción con potencias elevadas.
- El transporte: se centra en la construcción, operación y mantenimiento de las líneas de alta tensión que forman la base

del sistema eléctrico. La red de transporte enlaza centrales eléctricas con los puntos de utilización de la energía.

- La distribución: trata de la construcción, operación y mantenimiento de las líneas de media y baja tensión que suministran electricidad a usuarios finales.
- La comercialización: abarca los procesos relacionados con la venta de electricidad, excluyendo la entrega física de la misma.

De esta manera, el transporte y la distribución son actividades totalmente reguladas por el sistema cuando las actividades de generación y comercialización dejan de estar liberalizadas.

### **1.3. Agentes del mercado**

#### **1.3.1. Operador del Mercado**

El Operador del Mercado OMEL asegura la casación horaria de oferta y demanda, al coste mínimo. Su papel es más amplio y trata un conjunto de tareas como:

- Operar los Mercados Diario e Intradía incorporando las posiciones a plazo enviadas por el operador del mercado a futuro, OMIP.
- Realizar las comunicaciones derivadas de la Operación de los Mercados.
- Difundir la Información Pública
- Coordinar con otros mercados Internacionales
- Fomentar el desarrollo del Mercado.
- Cooperar con otras entidades en materia de previsión de la cobertura de la Demanda.
- Informar a las Administraciones sobre comportamientos contrarios al correcto funcionamiento del Mercado

#### **1.3.2. Operador del Sistema**

El operador del sistema, Red Eléctrica de España (REE), asegura la viabilidad técnica del sistema, cuyas funciones son:

- Garantizar el Equilibrio Técnico en las redes.

- Proponer y aplicar los criterios de Seguridad.
- Garantizar el acceso a la red de transporte.
- Proponer la Planificación de la red de Transporte.
- Establecer los requerimientos para la regulación del Sistema.
- Operación de los Mercados de SSCC y otros procesos de Operación Técnica, con inscripción de las Medidas Eléctricas
- Informar a las Administraciones sobre las situaciones excepcionales o de Emergencia.


### **1.3.3. Órgano Regulador**

El órgano regulador, la Comisión Nacional de la Energía (CNE), es el árbitro del sistema e interviene en caso de conflicto.

## **2. Conceptos de mercado y conceptos regulados**

### **2.1. Componentes del precio eléctrico**

Debido a su naturaleza medio regulada y medio liberalizada, el precio final que debe pagar el cliente está compuesto por varios conceptos que se pueden dividir en 2 partes distintas: los que dependen de la regulación en sí misma y que son fijados por ley, y los que dependen de los movimientos y niveles de los mercados eléctricos. El siguiente esquema reparte los conceptos que se exponen a continuación.



Componentes del Precio Eléctrico

## 2.2. Conceptos regulados

### 2.2.1. Pagos por capacidad

Su objeto es retribuir la permanencia e instalación de capacidad de generación. Asegura la existencia de suficiente potencia disponible en el sistema eléctrico para abastecer la demanda en todo momento. Los precios son fijados por el Ministerio de Industria y dependen del periodo horario de consumo y del nivel de tensión. ORDEN ITC/3353/2010 de 28 de Diciembre de 2010

### 2.2.2. Pérdidas

El paso de la energía por los diferentes elementos de una red (cables, transformadores o cualquier dispositivo) implica unas pérdidas. Son las pérdidas eléctricas que se producen en la red de transporte y distribución. Los coeficientes son porcentajes que dependen del periodo horario de consumo y del nivel de tensión. Dichos coeficientes son fijados por el Ministerio de Industria. REAL DECRETO 1634/2006 de 29 de Diciembre de 2006.

### 2.2.3. Tasa Local

Este impuesto es de carácter municipal por el suministro eléctrico dentro de un municipio. Corresponde a un porcentaje que se

aplica al comercializador por todos los conceptos del precio facturado (salvo impuestos y Tarifa de Acceso). El órgano regulador la fija en el 1,5 % de los ingresos brutos (sin Tarifas de Acceso y sin impuestos).

#### **2.2.4. Tasa OMIE**

Pago al Operador de Mercado de 0,0244 €/MWh por cada MWh que figure en el último programa horario final de cada hora.

#### **2.2.5. Tarifa de acceso**

Destinada a cubrir:

- Costes de uso de la red de transporte y de la red de distribución.
- Costes permanentes del sistema (sobrecoste extra peninsulares, CNE, operador del sistema y operador del mercado, etc.).
- Costes de diversificación y seguridad del abastecimiento (primas del régimen especial, costes del stock estratégico del combustible nuclear, etc.).

Esta tasa está definida en el RD 1164/2001, por el que se establecen tarifas de acceso a las redes de transporte y distribución de energía eléctrica. El precio es fijado por el Ministerio de Industria depende del periodo horario de consumo y del nivel de tensión.

### **2.3. Los mercados**

Es un Mercado en el que la entrega y el pago del bien negociado se efectúan en el momento de la operación. En España, ese mercado se estructura en los mercados de OMEL integrado por el mercado diario y el mercado intradiario, y a través de los mercados de servicios de ajustes.

#### **2.3.1. Los mercados SPOT**

##### **2.3.1.a. Mercado diario**

En él se realizan la mayoría de las transacciones de compra y venta de energía para el día siguiente. El Mercado Diario es el mercado más importante donde se negocia casi el 90 % de la energía.

Su funcionamiento es el siguiente: Antes de las 10.00h de cada día, los agentes del mercado deben enviar sus ofertas de compra y de venta de energía a las 24 horas del día siguiente. Tras el cierre de mercado, OMEL ordena las ofertas en función de su precio: curva agregada de venta/compra. El precio de las ofertas de venta representa el coste variable de cada grupo, que dependerá directamente del tipo de tecnología. Por ejemplo, en España, el fuerte incremento de la generación de origen renovable está teniendo un fuerte impacto en los precios de mercado.

OMEL realiza la casación para cada hora del día siguiente y determina el precio marginal del sistema al que compran/venden todos los agentes que han sido casados (ofertas de venta inferior al marginal y compra superior al marginal). Cada agente recibe información sobre la energía que ha resultado casada en cada hora. Este desglose constituye el programa de producción del día siguiente.

#### **2.3.1.b. Mercados Intradiarios**

Los agentes pueden acudir a los mercados intradiarios a modificar su programa comprometido como consecuencia de mejor información sobre la generación de sus grupos (Caída de una central de producción, Avenida de agua, etc) o el consumo de sus clientes (cambios temperatura, telemedida, etc)

- Obligación de participación previa de las comercializadoras en el mercado diario.
- También son gestionados por OMEL.
- Seis sesiones de intradiarios
- El mecanismo de casación es similar al del mercado diario

#### **2.3.2. Mercado de Futuro**

##### **2.3.2.a. Función**

La finalidad de un mercado a futuro es proponer a sus usuarios un cierto número de productos, o contrato, sobre un subyacente (en este caso la electricidad) a un precio determinado por contrato. De esta manera, el usuario no está pendiente de los resultados de casación de los mercados diario e intradiario previamente citados, y de sus fluctuaciones: se asegura por contrato con una entidad el suministro de cierto producto eléctrico a un precio cerrado. Se dice que traslada el riesgo a esta entidad.



Existen 2 tipos de mercados de futuro en España, que se detallan a continuación, los mercados organizados y los mercados OTC.

#### **2.3.2.b. Los mercados organizados: OMIP**

Su papel es estandarizar los contratos y los productos que se intercambian. Su principal órgano es la cámara de compensación y de liquidación (OMIClear) que gestiona y controla para que las garantías estén afianzadas o aseguradas. Sus reglas son las de un mercado organizado, es decir:

- Existe una regulación que normaliza los elementos del contrato como son sus activos subyacentes (ie: la electricidad), número de títulos, fecha de vencimiento y precio del ejercicio.
- Existe una cámara de compensación por la que se realizan las liquidaciones de los contratos, no teniendo que estar en contacto directo los compradores y los vendedores de lo mismo.
- La liquidez del mercado este asegurada ya que la sociedad intermediaria asume el riesgo de posible fallo.
- Proporcione una información transparente de las ofertas y demandas de contratos así como su cotización.

Así, OMIP compra a uno para vender a otros, haciendo respetar las normas en vigencia. Al pasar por la compra a futuro, las empresas ven sus riesgos disminuir, al ser asumido por OMIP. Por lo tanto, OMIP exige ciertas garantías a sus participantes ante posibles contingencias de riesgo.

#### **2.3.2.c. Los mercados OTC**

Además de los mercados organizados como OMIP, existen otras maneras de realizar transacciones, una de las más corrientes es pasando por los mercados Over The Counter (OTC).


Se trata de transacciones directas entre dos partes, sin cámara de compensación ni órgano de control de operación, tan sólo el acuerdo explícito contractual entre los dos firmantes. No existe publicación, ni información relativa a los intercambios realizados mediante ese mercado. Tampoco existe coste de intermediación, ni límite en las cláusulas de los contratos. Se suele usar para volumen más importante y suelen ser un poco más baratos que en los mercados organizados. Por lo tanto el riesgo de no cumplimiento

del contrato por parte de los actores existe y no está cubierto por ningún órgano.

#### 2.3.2.d. Los productos ofertados

OTC facilita, por su naturaleza, posibilidades de contrato más amplias que OMIP, aunque ambos proponen los siguientes productos “básicos”:

- **Producto BASE:** se trata de un producto que suministra un nivel de energía en carga base, es decir igual para cada hora del periodo del contrato, del volumen contratado y al precio contratado.
- **Producto PEAK:** suministra el nivel contratado, únicamente durante las horas dichas PEAK, es decir de las 8:00 a las 20:00. Suele ser un producto más caro que el producto BASE, pero en la mayoría de las necesidades de suministro es más “ajustado” a la curva de carga.



Productos Base y Peak.

Los periodos de contrato que están propuestos van desde las semanas más cercanas (ejemplo: Wk+1, Wk+2...), hasta periodos anuales (Cal+1, Cal+2...), pasando por los productos mensuales (M+1, M+2 etc...) o cuatrimestrales (Q+1, Q+2 etc...). Con esta gama de producto a disposición, las empresas tienen un abanico de estrategia de cobertura de riesgo más amplio.

### **2.3.3. Mercado de Ajustes**

El mercado de ajuste, o mejor los mercados de ajustes, es el encargado de asegurar el funcionamiento del sistema. Es decir, una vez finalizado los mercados diario o intradiario, existe un paso de regulación por parte del operador del sistema (REE) que va comprobando que dicha casación es viable desde el punto de vista del sistema. En caso de no ser así, se adoptan cierto número de restricciones técnicas y de regulación, lo que supone un cambio en la producción o la demanda, resultando en una nueva sesión de oferta por parte de los productores, o dicho de otra manera, un cambio de precio.

Es un mercado en el que se ajustan los desvíos de la producción o la demanda mediante mecanismos de subasta entre unidades de producción. Los desvíos generados (programa casado – consumo real) son penalizados a un precio medio ponderado resultante de los mercados de ajustes convocados por REE. Esas penalizaciones repercuten en el precio final de la energía, ponderadas por el consumo de desvíos de cada consumidor.

## Parte II

# Comercialización eléctrica

## 1. Comercialización y compartición del riesgo

### 1.1. Riesgo comercializadora y riesgo cliente

Por cada producto ofertado, hay un riesgo asociado que es diferente. Esta diferencia se debe a la cantidad de información que hay que prever en cada caso. Por ejemplo, un producto sin riesgo desde el punto de vista de la empresa ofertante, sería un producto que traslada al cliente todos los costes asociados a su consumo durante el periodo de contratación: en ese caso la empresa no tiene que prever cuales podrían ser esos costes, ya que los traslada todos.

Al revés, este tipo de configuración es muy arriesgada para el propio cliente que se ve sometido a las fluctuaciones de los mercados, que son los que fijarán sus costes. El riesgo para el cliente es máximo, ya que no tiene conocimiento de cómo se van a comportar. Además, la falta de visibilidad le puede ocasionar perjuicios, por ejemplo para su cierre contable, considerando que los costes reales pueden llegar mucho más tarde después del propio periodo de suministro (hasta un año). Por este tipo de razón, le viene mejor al cliente pagarlo definitivamente a la empresa a un precio determinado al momento de su consumo, y no estar pendiente de la lentitud del mercado.

Se puede encontrar un equilibrio mediante la posibilidad de contratar productos intermediarios, que permiten compartir los riesgos. Ahora que la empresa puede proponer precios más altos, a cambio de aumentar al mismo tiempo el riesgo que toma, se le abren las oportunidades para hacer beneficio.

### 1.2. Producto PASS-THROUGH

Este producto corresponde al caso sin riesgo por la empresa. Se trata de un producto en el que el cliente asume todo el riesgo (el Pool y resto de componentes). Al estar indexado al precio del Pool se verá beneficiado por las subidas y penalizado por las bajadas de precio.

Las desventajas que supone es una gestión difícil de la Tesorería

para el cliente y un impacto en la planificación de los presupuestos, al ser difícilmente previsible. Además, supone más complejidad en los procesos de gestión. Se necesita una facturación horaria. En caso de pagar los desvíos, el cliente tiene que gestionar su programación diaria el mismo etc...

Existe una variación de este producto, que hace asumir los desvíos (y la gestión de la programación diaria) a la empresa: el producto dicho PASS-THROUGH CON DESVIOS.



Productos PASS-THROUGH y PASS-THROUGH CON DESVIOS

### **1.3. Producto SEMI PASS-THROUGH**

Se trata de fijar todos los costes salvo el precio del pool y los desvíos del cliente. Es una oferta que refleja la situación de mercado en cada momento. El cliente se puede beneficiar de las posibles bajadas que se producen en el mercado. Supone simplicidad en la facturación respecto al Pass-Through. El riesgo es asumido por el cliente, el cual puede verse perjudicado por las subidas que se producen en el mercado. Al ser muy variable (con el pool) implica una gestión complicada de la tesorería y dificultades en la planificación de presupuestos.

### **1.4. Producto PASS-POOL**

Trata de fijar todos los costes salvo el del precio marginal del Pool. Es muy parecido al SEMI PASS-THROUGH.

### **1.5. Producto PRECIO FIJO**

La empresa asume todos los costes. Es el producto más arriesgado porque supone una buena visión del mercado a corto, medio y largo plazo. El riesgo no viene tan sólo del mercado sino también del propio consumo del cliente: se suelen insertar cláusulas de validez de la oferta en caso de cambio importante en la manera de consumir del cliente. La fijación de un precio fijo supone un buen conocimiento del cliente o de su sector. Los perfiles “arriesgados”, con muy poca regularidad o variaciones destacables frecuentes no se suelen ofertar a precio fijo.

## **2. La cobertura y la limitación del riesgo**

Nos ponemos en el caso de un “hedger”, es decir, un participante que va al mercado a futuro con el fin de reducir sus riesgos. Se dice que uno ha conseguido un “perfect hedge” cuando los riesgos están totalmente eliminados. Sin embargo, un “perfect hedge” es poco corriente, e incluso en la situación de un comerciante, casi imposible de conseguir.

## **2.1. Cobertura en Base o Cobertura en Pico.**


Se ha visto que dos grandes tipos de productos se intercambiaban en los mercados a plazo: los productos Base y los productos Peak o pico. Teniendo en cuenta el tipo de cliente y de perfil de consumo que tenemos, uno se puede valorar mejor que el otro. Los productos suministrados en Base corresponden al compromiso de tener durante todas las horas del periodo de contratación de dicho producto un volumen determinado a disposición. Los productos Peak son idénticos a excepción de que los periodos de suministro son limitados a los “periodos” pico, que son los días laborales entre las 8:00 y las 20:00. Para todo lo que pudiera pasar por debajo de este nivel, uno está “cubierto”.

## **2.2. Perfil de consumo cliente y prima de riesgo**

Consideremos que hemos cerrado una cobertura. Esta cobertura nos cubre solamente si el cliente tiene un consumo “plano” (tipo Base) o “localmente plano” (tipo Peak); no obstante, este tipo de consumo es poco probable. El cliente tiene más probabilidad de tener un consumo variable a lo largo del tiempo.

De esta variación, por pequeña que sea, nace un desequilibrio: cada MW por encima o por debajo de la cobertura se tiene que gestionar en el mercado diario, con todo el riesgo que conlleva, debido a la alta volatilidad de los precios que se negocian (ver gráfico más abajo). En el caso de tener energía que sobra en una hora particular, es decir, tener un consumo por debajo de mi cobertura, se va a tratar de venderla en el mercado diario. Por el contrario, si el cliente consume por encima de lo pactado, habrá que suministrarle la diferencia acudiendo a comprarla al spot.

Un desequilibrio puntual es aceptable a condición de que se compense con otro desequilibrio “inverso” en el periodo de contratación. El riesgo asociado con este fenómeno supone un sobrecoste para el cliente que contrata un producto, incluyendo un componente tipo “mercado” (precio de la energía o servicio complementarios y restricciones técnicas, o ambos), que llamaremos prima de riesgo.



Consumo frente a Mercado

### 3. La determinación de la prima de riesgo

La prima de riesgo está pensada para cubrir los costes asociados a un perfil no plano, debido al mecanismo descrito previamente. Se plantea ahora el problema de su evaluación. Existen varios métodos (dejados a la discreción de cada empresa suministradora), más o menos acertados, a la hora de considerar el problema, y la mayoría, sino todos, consideran dos criterios distintos en este cálculo:

- Las variaciones del consumo medio del cliente y del precio del mercado considerado, llamados riesgos Volumen.
- Las variaciones en la repartición del consumo, y del precio, en escalas más pequeñas, llamados riesgo Perfilado.



*¿Por qué esta división?* Por el propio método de cálculo: se trata de separar la previsión de un nivel “general”, digamos el precio/volumen medio del trimestre, de su granularidad, digamos los precios/ consumos horarios. Por lo tanto, parece lógico separar los conceptos de riesgo. Para la determinación de la prima habría que considerar los casos extremos y sus equivalentes monetarios. No obstante, al separar el cálculo de la prima se pierde la propia interacción que llevan estas dos previsiones, y todas las combinaciones posibles entre sí sobre el balance final. Nos ponemos de hecho en situaciones que, o no reflejan la previsión de un futuro plausible, o/y no consideran posibles compensaciones internas al definir casos extremos.

*¿Cómo evitar este problema?* Proponemos determinar el precio/ consumo mediante un modelo que permita introducir un factor aleatorio, plausible, expresión de los futuros posibles y trabajar con ellos. De esta manera, se deja al propio modelo la determinación de los casos extremos, tanto a nivel general, como a granularidades más finas, permitiendo de esta manera que coexistan localmente y que eventualmente se compensen. La determinación de la prima resultaría ser un análisis de las primas generadas por un número apreciable de simulaciones basadas sobre el modelo definido.

## Parte III

# Fundamentos teóricos

*Nota previa:* La mayoría de los conceptos desarrollados en esta parte son resultantes de las obras de Charpentier A. (2) y de Prenat M. (10).

## 1. Concepto de serie temporal

### 1.1. ¿Qué es una serie temporal?

Al contrario que con la economía tradicional, el objetivo del análisis de las series temporales no es relacionar variables entre sí, sino más bien centrarse en la dinámica de una variable. Efectivamente esta última es esencial, en base a dos razones:

- Los avances en econometría han subrayado que solamente se pueden relacionar variables que tienen propiedades similares, en particular una misma estabilidad o inestabilidad
- Las propiedades matemáticas de los modelos, que permiten estimar la relación entre dos variables en base a su dinámica.

Por lo tanto, una serie temporal se podría definir como una serie de observaciones de una variable en distintas fechas. Se trata de un análisis histórico de las fluctuaciones de una misma variable a lo largo del tiempo para poder entender su dinámica.

### 1.2. Principales objetivos

Dentro de los objetivos de un estudio en serie temporal, se pueden destacar tres principios comunes:

- Prever: La primera función para la cual es interesante observar el histórico de una variable, es para determinar ciertas regularidades con el fin de poder establecer una previsión, basándose sobre el lema de que las mismas causas producen los mismos efectos.
- Relacionar: Se trata de crear vínculos entre variables para establecer comparaciones y correlaciones entre series. Podemos así asociar relaciones que interactúan con la serie observada.

- Determinar causalidad: Se trata de determinar la noción de fuente. La utilización de retraso de una variable permite, a partir de los valores de los periodos precedentes, adivinar la duración de transmisión entre una fuente y su efecto.

### 1.3. Procedimiento

#### 1.3.1. Objetivo

El objetivo que se persigue es la formulación de un modelo estadístico que sea una representación congruente, es decir, que sea conforme a los datos desde cualquier punto de vista medible del proceso estocástico desconocido que ha generado la serie observada. Del mismo modo que con la probabilidad, hay que entender la diferencia entre el proceso que genera los datos, su realización al ser observado sobre las muestras históricas a disposición, las futuras realizaciones, y el modelo que construimos intentando representarlo.

#### 1.3.2. Resultado

Adoptando un enfoque condicional sobre el pasado del proceso observado, es decir expresando la variable al instante  $t$  como función de los instantes  $t_0$  hasta  $t-1$ , conseguimos una descomposición Previsión/Error, sobre la cual uno se puede basar para hacer previsiones (parte Previsión) y evaluar la posible desviación sobre ella (parte Error, es decir la parte “imprevisible”).

## 2. Definición

Antes de definir “matemáticamente” una serie temporal, son necesarias ciertas definiciones y recuerdos.

### 2.1. Estacionariedad

#### 2.1.1. Definición

*Recuerdo:* Función de covarianza de un proceso aleatorio:

$$Cov(t, s) = Cov(X_t, X_s) = \mathbb{E}([X_t - \mathbb{E}(X_t)][X_s - \mathbb{E}(X_s)])$$

Digamos que  $X_t$  es débilmente estacionario cuando:

$$\begin{cases} \forall t \in \mathbb{Z}, \mathbb{E}(|X_t|^2) < \infty, \\ t? \mathbb{E}(X_t) \text{ est constante,} \\ \forall r, s, t \in \mathbb{Z}, Cov(X_r, X_s) = Cov(X_{r+t}, X_{s+t}) \end{cases}$$

Es decir, si los primeros momentos (media y esperanza matemática) y segundos (varianza y autocovarianza) son procesos que existen y son independiente de  $t$ .

La Estacionaridad es una propiedad de estabilidad: la distribución de  $y_t$  es igual a la de  $y_{t+1}$ . La serie oscila alrededor de su media con una varianza constante. Por lo tanto, el vínculo entre  $y_t$  y  $y_{t+h}$  depende únicamente del intervalo  $h$  y no de la fecha  $t$ .

Para comprobar la estacionalidad de una serie se usarán varios tests, dos de los cuales se usan en la mayoría de los casos: el test DFA y el test PP.

### 2.1.2. DFA

El Test de Dickey-Fuller Aumentado o DFA es un test de raíz unitaria. Consiste en efectuar la regresión 1 y examinar el carácter significativo del coeficiente  $(\rho - 1)$  con la ayuda de los umbrales de MacKinnon.  $D_t = \mu + \alpha t$  es la parte determinista de la serie,  $\alpha$  y  $\mu$  pudiendo ser nulos.

$$\Delta Y_t = D_t + (\rho - 1)Y_{t-1} + \sum_{i=1}^{p-1} (\phi_i \Delta Y_{t-i}) + \epsilon_t \quad (1)$$

Dickey-Fuller Aumentado: test de raíz unitaria
--

- |   |
|---|
| <ul style="list-style-type: none"> <li>- <math>H_0 : \rho - 1 = 0</math> en la regresión 1. Raíz unitaria, no estacionariedad</li> <li>- <math>H_1 : \rho - 1 &lt; 0</math> Estacionariedad de la serie</li> <li>- estadístico de test: t-estadístico del coeficiente <math>(\rho - 1)</math></li> <li>- rechazo de <math>H_0</math> : umbrales de MacKinnon</li> </ul> |
|---|

### 2.1.3. Phillips-Perron

El test de Phillips-Perron es una adaptación del test DFA de raíz unitaria, usado en presencia de errores heteroscedásticos y/o autocorrelacionados, calculando esta vez otra estadística de test definida por y comparando los diferentes umbrales de MacKinnon.

Phillips-Perron: test de raíz unitaria
--

- |   |
|---|
| <ul style="list-style-type: none"> <li>- <math>H_0 : \rho - 1 = 0</math> en la regresión 1. Raíz unitaria, no estacionaridad</li> <li>- <math>H_1 : \rho - 1 &lt; 0</math> estacionaridad de la serie</li> <li>- rechazo de <math>H_0</math> : umbrales de MacKinnon, tabla ??</li> </ul> |
|---|

## 2.2. Ruido Blanco

### 2.2.1. Definición

Un ruido blanco es un proceso estacionario débil de media cero y que esta dinámicamente no correlacionado. Si  $\{u_t\}$  es un ruido blanco pues:

$$\begin{cases} \forall t \in \mathbb{Z}, \mathbb{E}(X_t) = 0, \\ \forall t \in \mathbb{Z}, \mathbb{E}(X_t^2) < \infty, \\ \forall t \in \mathbb{Z}, \tau \neq t, \mathbb{E}(X_t X_\tau) = 0 \end{cases}$$

### 2.2.2. Ljung-Box

El test de Ljung-Box permite evaluar las autocorrelaciones de los residuos de una modelización ARMA( $p, q$ ).

Ljung-Box: test de ruido blanco
---------------------------------

- |   |
|---|
| <ul style="list-style-type: none"> <li>- <math>H_0 : \rho_1 = \rho_2 = \dots = \rho_K = 0</math></li> <li>- <math>H_1 : \exists i \in 1, \dots, K : \rho_i \neq 0</math></li> <li>- estadístico de test: <math>Q' = n(n+2) \sum_{k=1}^K (\frac{\hat{\rho}(k)}{n-k})</math></li> <li>- rechazo de <math>H_0 : Q' &gt; \chi_{K-(p+q)}^2(1-\alpha)</math></li> </ul> |
|---|

Para usar ese test esta recomendado elegir K cerca del tercio del número de observación.

## 2.3. ACF y PACF

La autocorrelación es simplemente la correlación de un proceso con respecto a una versión del mismo desfasada en el tiempo. Se define por:

$$\rho_X(h) = \text{Corr}(X_t, X_{t-h}) = \frac{\text{Cov}(X_t, X_{t-h})}{\sqrt{V(X_t)}\sqrt{V(X_{t-h})}}$$

donde  $V(X_t)$  es la varianza del proceso  $X_t$ , definido por:

$$V(X_t) = E(X_t^2) - E^2(X_t)$$

De manera general, una correlación parcial entre dos variables es la cantidad de correlación que no está explicada por las relaciones de esas variables, con un conjunto específico de otras variables. En el caso de serie temporal, la correlación parcial de desfase  $k$  es la correlación entre  $y_t$  y  $y_{t-k}$  que no está explicada por el valor de las  $k$  autocorrelaciones interpuestas. Se define por:

$$\phi_X(h) = \text{Corr}(\hat{X}_t, \hat{X}_{t-h})$$

donde

$$\begin{cases} \hat{X}_{t-h} = X_{t-h} - EL(X_{t-h}|X_{t-1}, \dots, X_{t-h+1}) \\ \hat{X}_t = X_t - EL(X_t|X_{t-1}, \dots, X_{t-h+1}) \end{cases}$$

y  $EL(X_i|X_{t-1}, \dots, X_{t-h+1})$ , las proyecciones (*o esperanzas lineales*) de los valores extremos sobre el conjunto de los valores intermedios.

### 3. Procesos SARIMA

Existen dos categorías de modelos para interpretar una serie temporal. Los primeros consideran que los datos son una función del tiempo,  $y = f(t)$ . Esta categoría de modelo puede estar ajustada por el método de los mínimos cuadrados, u otros métodos iterativos. Una segunda categoría de modelo intenta determinar cada valor de la serie en función de los valores que la preceden. Eso es el caso de los modelos ARMA, del inglés “Auto Regressive Moving Average”, formalizados por Box y Jenkins.

#### 3.1. Procesos ARMA

##### 3.1.1. Definición

Digamos que  $X_t$  sigue un proceso ARMA( $p, q$ ) cuando comprueba las condiciones siguientes:

$$\begin{cases} (X_t) \text{ es estacionario,} \\ X_t - \Phi_1 X_{t-1} - \dots - \Phi_p X_{t-p} = Z_t + \Theta_1 Z_{t-1} + \dots + \Theta_q Z_{t-q}, \end{cases}$$

Donde  $Z_t$  es un ruido blanco.

En este nivel sería interesante entender el sentido teórico de estos procesos. Esta interpretación dependerá de la naturaleza del fenómeno estudiado, así como de los modelos que el investigador tenga a su disposición para exponerlo.

Un proceso de media móvil sugiere que el valor de referencia evoluciona de una medida a otra, es decir, cada punto es función de los errores incluidos en los puntos precedentes, más su propio error. Un proceso autoregresivo sugiere que el fenómeno estudiado no está determinado por un valor de referencia. Es el comportamiento precedente (o los comportamientos precedentes) lo que determina enteramente el comportamiento presente.

### 3.1.2. Identificación de los órdenes $p$ y $q$ del modelo.

Se trata de usar las características específicas de los subprocesos AR y MA que componen el proceso. Una primera estimación del orden  $p$  de un proceso  $AR(p)$  puede estar hecha usando la propiedad de la función de autocorrelación parcial empírica:

- Su función de autocorrelación parcial vale 0 para  $h > p$
- para  $h > p$ , la función de autocorrelación parcial empírica es asintóticamente gaussiana de media 0 y de varianza  $\frac{1}{n}$ .

Del mismo modo, una primera estimación del orden  $q$  de un proceso  $MA(q)$  sería en base a la propiedad de su función de autocorrelación empírica:

- La función de auto correlación vale 0 para  $h > q$
- para  $h > q$ , la función de autocorrelación empírica es asintóticamente gaussiana de media 0 y de varianza  $1/n$ .

### 3.1.3. Validación de modelo

La validación de un modelo se efectúa mediante un criterio de control del residuo. Durante la predicción de un proceso ARMA, se genera una serie de residuos. Cuando se ha predicho correctamente, la serie de los residuos es un ruido blanco.

El test portmanteau se basa sobre un dato único construido sobre la correlación empírica de los residuos. En este estudio se usará el test de Ljung-Box.

### 3.1.4. Método de selección

A un proceso se pueden asociar muchas combinaciones de  $p$  y  $q$  que serían coherentes. Se propone usar un método para poder comparar esos modelos entre ellos. En este estudio se usarán los

criterios de cantidad de información o criterios AICC y AIC, que permiten evitar el fenómeno de “sobreajuste”.

Aunque en la teoría nada impide estimar un proceso ARMA( $p, q$ ) con órdenes más grandes, en la práctica ello engendraría un aumento del error de estimación de los parámetros y un mayor riesgo de encontrar un modelo que esté demasiado cerca de la realización particular observada. El criterio de Akaike corregido tiene por objetivo encontrar un compromiso entre la verosimilitud de las observaciones con respecto al modelo y la complejidad del mismo modelo. Se define por:

$$AICC(\phi, \theta) = -2\log L(\phi, \theta, n^{-1}S(\phi, \theta)) + 2(p + q + 1) \frac{n}{n - p - q - 2}$$

Donde:

- $L(\phi, \theta, \sigma^2)$  es la verosimilitud de los datos para un modelo ARMA( $p, q$ ) gaussiano con los parámetros  $(\phi, \theta, \sigma^2)$ ,
- $S(\phi, \theta)$  es la suma de los cuadrados de los residuos.

Para  $n$  dado, el segundo término de la fórmula que da AICC aumenta con la complejidad del modelo, es decir con  $p$  y  $q$ . Es un término de penalización. Elegimos entonces el conjunto  $(p, q, \phi, \theta, \sigma)$  que minimiza este criterio.

## 3.2. Generalización

Los procesos SARIMA son procesos aleatorios no estacionarios que tienen tendencias aleatorias y/o variaciones temporales aleatorias.

### 3.2.1. Definición

El proceso  $X_t$  se le llama SARIMA( $p, d, q$ )( $P, D, Q$ ) $_s$  si el proceso diferenciado:

$$Y_t = (1 - B)^d (1 - B^s)^D X_t$$

es un proceso ARMA tal que:

$$\Phi(B)\Phi_s(B^s)Y_t = \Theta(B)\theta_s(B^s)Z_t$$

Donde  $\Phi$  y  $\Theta$  son polinomios de grados respectivos  $p$  y  $q$ :

$$\begin{aligned}\Phi(z) &= 1 - \sum_{i=1}^p (\phi_i z^i) \\ \Theta(z) &= 1 + \sum_{i=1}^q (\theta_i z^i)\end{aligned}$$



y  $\Phi_s$  y  $\Theta_s$  son polinomios de grados respectivos  $P$  y  $Q$ :

$$\begin{aligned}\Phi_s(z) &= 1 - \sum_{i=1}^P (\phi_{s,i} z^i) \\ \Theta_s(z) &= 1 + \sum_{i=1}^Q (\theta_{s,i} z^i)\end{aligned}$$

### 3.2.2. Principios de identificación

En un proceso SARIMA hay interacción entre dos modelos: uno que describe las evoluciones durante el periodo de la muestra, es decir entre dos “temporadas” sucesivas, y otro que describe las evoluciones durante el periodo de la temporada. Esta interacción hace que la interpretación de la covarianza en el caso general sea compleja.

Se indican aquí algunos principios elementales para una identificación simple, con la hipótesis de que existe un desacoplamiento entre los dos modelos: En otros términos, que la función de correlación determinada por los polinomios  $\Phi$  y  $\Theta$  alcance valores lo suficientemente pequeños para  $t = s/2$ . Podemos usar entonces el procedimiento siguiente:

- encontrar los órdenes  $d$  y  $D$  de tal forma que el proceso

$$Y_t = (1 - B)^d (1 - B^s)^D X_t$$

sea estacionario

- usar la correlación empírica y la correlación parcial empírica para los valores múltiplos de  $s$  para deducir valores preliminares de los órdenes  $P$  y  $Q$
- usar la correlación empírica y la correlación parcial empírica para valores hasta  $s/2$  para deducir los órdenes  $p$  y  $q$ .

Los procesos de control y ajuste descritos para un modelo ARMA siguen siendo aplicables.

## 4. Procesos GARCH

### 4.1. Contexto

Hemos visto en las partes anteriores que un proceso  $X_t$  se llama ARMA( $p, q$ ) si podemos escribir

$$X_t = \phi_1 X_{t-1} + \dots + \phi_p X_{t-p} + Z_t + \theta_1 Z_{t-1} + \dots + \theta_q Z_{t-q}$$

donde  $Z_t$  es en general un ruido blanco debil:

$$Z_t \sim i.i.d.(0, \sigma_Z^2)$$

$Z_t$  es una serie de variables aleatorias independientes y idénticamente distribuidas, de media 0 y de varianza  $\sigma_Z^2$ .

Este asunto es importante a la hora de tratar con series financieras así que se ha creado un proceso que permita explicar mejor la dinámica de los residuos precedentes. Los modelos GARCH favorecen el agrupamiento de fuertes variaciones sobre ciertos periodos (aparición de correlaciones empírica cuando la varianza está elevada). Lo encontramos a menudo por ejemplo en series financieras donde los periodos de fuerte variación contrastan con periodos más tranquilos.

## 4.2. Definición

Un proceso  $\epsilon_t$  está llamado GARCH( $p, q$ ) si:

$$\epsilon_t = \sigma_t \eta_t$$

donde

$$\eta_t \sim i.i.d(\mathcal{N}(0, 1))$$

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^p (\alpha_i \epsilon_{t-i}^2) + \sum_{j=1}^q (\beta_j \sigma_{t-j}^2)$$

con  $\alpha_0 > 0, \alpha_i \geq 0$  para  $i > 0$  y  $\beta_j = 0$  para  $j > 0$

De manera clásica, la variable aleatoria  $\eta_t$  puede seguir, en vez de una ley gaussiana, una ley de Student con  $\nu$  grados de libertad y de varianza 1 que presenta colas de distribución más importantes que las de la ley normal.

## 4.3. Testar la presencia de un efecto GARCH en el residuo

Basta de pasar por el análisis de la correlación empírica de la serie de los cuadrados de los residuos. Si una dependencia esta visible, es signo de la presencia de un efecto GARCH. Un test de Ljung-Box sobre los residuos es posible también.

## 4.4. Validez de un modelo GARCH

La comprobación del carácter *i.i.d.* de los residuos es índice de una buena modelización.

## 5. Bootstrap

La idea de un bootstrap es que, como la mejor aproximación que tenemos del comportamiento de una población es a menudo la muestra que disponemos de ella, vamos a usar esta muestra para crear artificialmente una serie de muestras que intentan aproximar el comportamiento de la población subyacente. Con un número de generación lo suficientemente grande, se pueden sacar unas informaciones acerca de la serie inicial.

La manera más sencilla para un bootstrap es de construir la nueva muestra de la misma talla eligiendo al azar sus elementos dentro de la muestra empírica que tenemos, y así conservar las propiedades subyacentes de la distribución. Existen muchas otras maneras de construir la muestra bootstrap, más o menos complicada, como añadiendo un ruido blanco de pequeña amplitud al anterior (*smooth bootstrap*), multiplicandolo por una variable de media 0 y de varianza 1 (*wild bootstrap*) o también considerando la elección por bloque de los valores (*moving block bootstrap*).

Una limitación importante es el carácter *i.i.d.* de la distribución que se intenta reproducir: si existen correlaciones, el bootstrap va a hacer desaparecer esas relaciones en la muestra generada. La alternativa es de construir un modelo mediante un bootstrap llamado paramétrico, que se ajusta a un modelo probabilístico existente (por ejemplo, una ley normal, de Student...).

Adèr, Mellenbergh Hand (14) recomiendan usar el bootstrap cuando la distribución teórica es complicada o desconocida.

## 6. Software

A lo largo del diseño del proyecto como de su redacción se ha utilizado tres herramientas principalmente:

### 6.1. R

El proyecto se basa principalmente sobre el programa libre de computación y de análisis, R. La integralidad de los cálculos han

estado efectuados con los paquetes puestos a disposición por el programa. Los manuales usados principalmente para la formación en R son los de Shumway Stoffer (4) y de Paradis E. (6) para la parte de programación y [duclert.org](http://duclert.org) (5) para la parte gráfica.

*¿Por qué R?* Por una razón principal: el acceso a su código debido a su carácter libre. En efecto, a lo largo del estudio se ha hecho sentir la necesidad de poder alejarse de las herramientas diseñadas entregadas con los programas de análisis. Por ejemplo, a la hora de plantear una solución que consideraba un diseño tipo SARIMA con unos residuos tipo GARCH, esta solución no estaba implementada de manera fácil y usable por uno de los programas internos. La potencia de un programa libre se revela plenamente en esos momentos: poder crear a partir de soluciones existentes una nueva a medida, sin tener que entrar en la complejidad de una programación pura en lenguaje de alto nivel. Una razón un poco distinta pero muy relacionada que me ha convencido a usar la potencia de R, es el acceso de manera simple a una documentación, unos paquetes y unas soluciones, en abundancia, actualizadas y coherentes entre si.

A esta(s) razón(es) primaria(s), se podrían sumar dos secundarias: su generación gráfica de muy alta calidad por la parte de redacción, y su facilidad de uso para mí debido a que ya tenía conocimiento de su funcionamiento básico, gracias a mi carrera.

## 6.2. $\text{\LaTeX}$

$\text{\LaTeX}$  resultó ser una de las herramientas más prácticas a la hora de redactar la presente memoria. Separando la redacción propia del resultado final, permite centrarse en el contenido y no perder tiempo en considerar aspectos de presentación:  $\text{\LaTeX}$  lo hace él mismo, siguiendo los órdenes generales definidos dentro del código, o aplicando los que juzgue adecuados si no están definidos. Además por quien escribe formulas matemáticas, el resultado conseguido es de los mejores posibles, y eso para una inversión de tiempo mínima en redacción.

## 6.3. Powerpoint

De manera muy puntual para la redacción de la presente memoria se ha preferido usar el interfaz gráfico de powerpoint: la gestión de forma y de sus desplazamientos relativos reveló ser más adecuado por el diseño de unos gráficos, que hubieran necesitado más tiempo en generar con R. Por otra parte, la presentación oral se realiza con

Powerpoint.

## Parte IV

# Aplicación: Determinación de la prima de riesgo

## 1. Planteamiento

### 1.1. Estrategia

Se considerara aquí el caso de fijación de precio para un producto tipo Precio Fijo. La empresa a quien se hace la oferta es un cliente industrial, que presenta “muchas” regularidad en su carga de consumo. Tal y como hemos visto en la segunda parte, para poder evaluar la prima de riesgo asociada a la variación de un componente del precio en relación con un mercado vamos a utilizar un procedimiento basado en la creación de un modelo. Dicho modelo servirá de base a la simulación de futuros realizables de la variable de mercado que se mide.

La estrategia de la empresa es de cerrarse basándose en el mercado a futuro, comprando todos los productos del periodo de contrato en el momento de la aceptación de la oferta por parte del cliente. Para un contrato que va desde Enero 2012 hasta Diciembre 2012 y una oferta el día 30 de diciembre 2011, la empresa compra el volumen de cobertura en el mercado OTC ese mismo día a precio del mercado OTC por cada uno de los cuatro productos 2012Q1, 2012Q2, 2012Q3 y 2012Q4.

### 1.2. Simplificaciones

En este proyecto consideramos solamente el caso de la evaluación de la prima del componente energía del precio. Los conceptos de restricciones técnicas y servicios complementarios siguen el mismo método con la excepción de que, no estando planteada la cobertura, se usaría una definición del volumen de cobertura igual a cero.

El tema de la dinámica de los desvíos se soluciona considerando aplicar el efecto cartera: es decir que los desvíos aplicados a un cliente particular se compensan con los desvíos de otros clientes de la cartera que se desvían en sentido opuesto. Se considera que la empresa ha conseguido un número crítico de clientes en sectores diversificados para aplicar la hipótesis del efecto cartera.

Con respecto a la carga de consumo del cliente no se ha considerado relevante modelarla a futuro: siendo un cliente industrial tiene mucha regularidad de consumo debida a la regularidad de sus propios procesos de funcionamiento interno. Así, no cambiará significativamente su manera de consumir y se considerará una buena aproximación utilizar su consumo real pasado ya que seguirá la misma dinámica que el año en curso. Se introducen cláusulas de revisión de precio en caso de cambio impactante en los procesos de la empresa (renovación del parco de maquina, añadido de procesos etc. . . ). Se puede “limpiar” los datos previamente para corregir cualquier dato visiblemente no pertinente para el estudio (una parada no prevista, un error del aparato de medida. . . ).

### 1.3. Datos

Los datos usados para la evaluación del modelo se componen de los precios horarios de dos años completos, 2010 y 2011. Los precios horarios de la primera parte del año 2012 sirven de referencia para poder evaluar la calidad de la previsión conseguida. Al usar datos de frecuencia tan alta, y sobre periodos de tiempo tan largos, multiplicamos el número de observaciones y entonces la posibilidad de dejar correlaciones en los residuos finales del modelo. Esto implica que el modelo podrá difícilmente conseguir la explicación de todas las dependencias de los datos.

### 1.4. Método

Vamos a seguir un método en 5 pasos que podríamos definir así:

- Modelización: intenta sentar las bases de la dinámica del precio spot.
- Simulación: Lanzar un número de veces muy grande (del orden de 10 000 para poder tener resultados aceptables) unas simulaciones de lo que podrían ser los precios para el periodo de contrato considerado.
- Efectuar el balance enfrentando las simulaciones con el perfil de consumo del cliente.
- Determinar el volumen óptimo de cobertura.
- Determinar la prima de riesgo.

## 2. Determinación del modelo

### 2.1. Método

Debido a la muy alta complejidad de este mercado y como consecuencia directa de su carácter muy peculiar dentro de las “commodities”, principalmente por razones técnicas, la estrategia ha sido separar los problemas mediante una división de la modelización de la serie inicial en un estudio por modelos aditivos. Esta elección se justifica con el estudio de las dinámicas intrínsecas a cada uno de los componentes del modelo aditivo, como son la presencia de volatilidad muy alta a nivel horario, característica típica de los mercados financieros, y la persistencia de rasgos estacional claramente destacables a nivel anual, diario e incluso horario.

Por tales razones se ha decidido dividir el estudio en tres partes interrelacionadas entre sí:

- una parte anual que intenta recoger las variaciones más amplias de evolución de la serie original: la serie  $Y_t$ ,
- una parte diaria que subraya la similitud semanal y diaria de la serie: la serie  $D_t$ ,
- una parte horaria que trata de capturar las dependencias que existen en los movimientos intradiarios: las series  $H_{i,t}$ .

### 2.2. Serie $Y_t$

#### 2.2.1. Objetivo

Sabiendo la importancia del tiempo, temperatura, viento, lluvia etc. . . como fundamentos en la determinación de los precios, parece lógico que la dinámica de los precios refleje la dinámica relativa de sus fundamentos. Considerar efectos estacionales del periodo de orden de magnitud del año, el orden de movimiento de los fundamentos citados por medio de una regresión harmónica de periodo ad-hoc tendría sentido.

A esto se le pueden superponer efectos a largo plazo traduciendo una evolución de la demanda, ligera pero permanente, cuando las tecnologías de producción más baratas guardan una capacidad de suministro igual a lo largo del tiempo. La consecuencia directa de esta diferencia sería la existencia de un aumento lineal en los precios spot.



### 2.2.2. Modelización

Por lo tanto, vamos a examinar una modelización por medio de una regresión armónica con termino de tendencia lineal :

$$Y_t = A \cos\left(\frac{2\pi t}{24 * 365}\right) + B \sin\left(\frac{2\pi t}{24 * 365}\right) + Ct + D \quad (2)$$

### 2.2.3. Resultados

Coeficiente	Valor
A	-2.014644'***'
B	-3.109213'***'
C	0.001335'***'
D	32.530644'***'
$R^2$	0.3982

Computación: `lm(data ~ formula)`

- data:
- fórmula:  $\cos(2*\pi/(24*365)*t) + \sin(2*\pi/(24*365)*t) + t$

## 2.3. Serie $D_t$

### 2.3.1. Objetivo


El objetivo de esta serie es determinar la dinámica entre los días de los residuos previamente definidos por el modelo  $Y_t$ . Entonces, no se considerará más la serie horaria sino una agrupación por día de los residuos, que corresponde a la media del valor del residuo por día.

### 2.3.2. Normalidad

Los residuos conseguidos no son normales como se puede ver en los QQ-plots a continuación. No tienen porque ser normales en esta etapa de la modelización pero la experiencia financiera con respecto a ese tema intenta acercarse a la normalidad considerando los logaritmos de los precios, evitandose problemas de no normalidad más tarde. El problema de los valores negativos que surge a la hora de pasar al logaritmo se corrige de forma aproximada con la introducción de una constante. Consideramos ahora la serie:

$$D_t^* = \log(D_t + \min_{t \in \mathbb{Z}}(D_t) + 1) \quad (3)$$

Habría que tenerla en cuenta después de que la transformación inversa esté hecha.



### 2.3.3. Hipótesis

Para poder aplicar a una serie un proceso tipo ARMA, el requisito de Estacionariedad de la serie es imprescindible. La serie no parece ser estacionaria en el gráfico 1, así que vamos a efectuar una diferenciación de intervalo 7, debida al carácter semanal de mi serie. Consideramos a partir de ahora la serie:

$$D_t^{**} = D_t^* - D_{t-7}^* \quad (4)$$

La serie  $D_t^{**}$  no pasa el test de Estacionariedad según Dickey-Fuller pero si el test según Phillips-Perron. Al ver la curva de  $D_t^{**}$  1, se nota que presenta índices de heterocedasticidad: la volatilidad no es constante a lo largo del tiempo con fenomenos de clustering...


Hemos visto que en caso de heterocedasticidad, el test de Phillips-Perron era más adaptado, entonces consideramos que la serie  $D_t^{**}$  es estacionario.

Resultados de los test de Estacionariedad de la serie  $D_t^{**}$

Conceptos	DICKEY-FULLER	PHILLIPS-PERRON
Estadística	36.87	-321.25
Lag Order	8	6
p-value	> 0,99	< 0,01

Computación: `adf.test(x, alternative, k )`

■ x: data



Cuadro 1: Serie  $D_t$  y Serie  $D_t^{**}$


- alternative: "stationary"
- k:  $\text{trunc}((\text{length}(x)-1)\hat{1}/3)$

Computación: `pp.test(x, alternative, type )`

- x: data
- alternative: "stationary"
- type = "Z(alpha)"

#### 2.3.4. Modelización



El carácter estacionario habiendo sido comprobado se puede efectuar el análisis siguiendo los pasos definidos en la parte teórica.





ACF y PACF de la serie  $D_t^{**}$

Arriba, se exponen los autocorrelogramas ACF y PACF de la serie diferenciada: la forma muy peculiar de esas correlaciones, con la presencia de una correlación importante en los múltiplos de 7, confirman el carácter estacional de periodo 7 de la serie. La presencia de un término importante en el lag 1 del PACF asociado a un decrecimiento exponencial del ACF entre  $lag = 1$  y  $lag = 7$ , es característica de un modelo tipo AR(1). Además la fuerte correlación en el ACF para  $lag = 7$ , asociada con un decrecimiento exponencial en el PACF de las correlaciones múltiplos de 7 es la huella de la presencia de un AM(1) para el término estacional del SARIMA.

Probamos primero el ajuste con un modelo SARIMA(1, 0, 0)(0, 1, 0)<sub>7</sub>. Los auto correlogramas siguientes reflejan lo que habíamos intuido:




ACF y PACF de los residuos de un  $\text{SARIMA}(1, 0, 0)(0, 1, 0)_7$  a  $D_t^*$



ACF y PACF de los residuos de un  $\text{SARIMA}(1, 0, 0)(0, 1, 1)_7$  a  $D_t^*$

A la vista, los autocorrelogramas de los residuos de un  $\text{SARIMA}(1, 0, 0)(0, 1, 1)_7$  parecen aceptables y haber explicado buena parte de las dependencias aunque quedan unas correlaciones no explicadas. Aumentar el número de variable en este modelo mejora ligeramente mi criterio AIC, pero no me quita todas las correlaciones remanentes en los residuos. El modelo final será un modelo  $\text{SARIMA}(1, 0, 0)(0, 1, 2)_7$  y el ACF y PACF de sus residuos:



ACF y PACF de los residuos de un SARIMA(1, 0, 0)(0, 1, 2)<sub>7</sub> a  $D_t^*$

Computación: `arima(x, order, seasonal, include.mean, method)`


- x: data
- order: `c(1,0,0)`
- seasonal : `list(order = c(0, 1, 2), period = 7)`
- include.mean: TRUE
- method: "ML"

### 2.3.5. Validación

Para poder satisfacer plenamente las condiciones de aplicación, el residuo debe ser un ruido blanco distribuido normalmente.

#### 2.3.5.a. Normalidad

La distribución de los residuos enseña un exceso de kurtosis, pero ningún método de ajuste en el programa usado permite asociar un SARIMA con una distribución que no sea gaussiana. Entonces vamos a seguir en la modelización e intentaremos tener en cuenta el carácter no gaussiano de los residuos en las simulaciones.



QQ-Plot y Densidad estimada de la serie de los residuos de la serie  $D_t^*$

### 2.3.5.b. Ruido blanco

Los resultados están expuestos en la siguiente tabla:

LJUNG-BOX	Valor
K	240
df	233
$\chi^2$	232.145
p-value	0.504

Resultados de los test de ruido blanco de los residuos


Aceptamos la hipótesis nula de homoscedasticidad: el residuo se puede considerar como ruido blanco.

Computación: `Box.test(x, lag, type, fitdf)`


- x: data
- lag: `trunc((length(x)-1)*(1/3))`
- type : "Ljung-Box"
- fitdf: `ar1 + sam1 + sam2 = 3`

### 2.3.6. Transformación

Se crean los residuos como la diferencia entre los residuos primarios resultante del modelo  $Y_t$  y la transformación inversa de la parte explicada del ajuste del modelo  $D_t^{**}$ , al cual restamos la constante ficticia que habíamos introducido al principio del estudio. Conseguimos el ajuste siguiente para el modelo  $D_t$ .



## 2.4. Series $H_{i,t}$





### 2.4.1. Transformación

Tenemos una serie de residuos que corresponden a días distintos de la semana, pero quiero que se tenga en cuenta el comportamiento propio intradiario por cada día. Entonces transformamos la serie inicial en siete series, una por cada día de la semana. Las series están ahora centradas en cero aproximadamente. La misma técnica está usada antes de pasar al logaritmo para evitar los problemas de valor negativo:

$$H_t^* = \log(H_t + \min_{t \in \mathbb{Z}}(H_t) + 1) \quad (5)$$

A continuación exponemos el caso de la serie de los lunes.

### 2.4.2. Hipótesis

Los autocorrelogramas de las series brutas, sin diferenciación, hacen aparecer un componente no estacionario: la correlación a 24 horas se está difundiendo a lo largo de los lags. A la vista, una diferenciación con un intervalo de 24 resuelve este problema. Consideramos a partir de ahora las series:

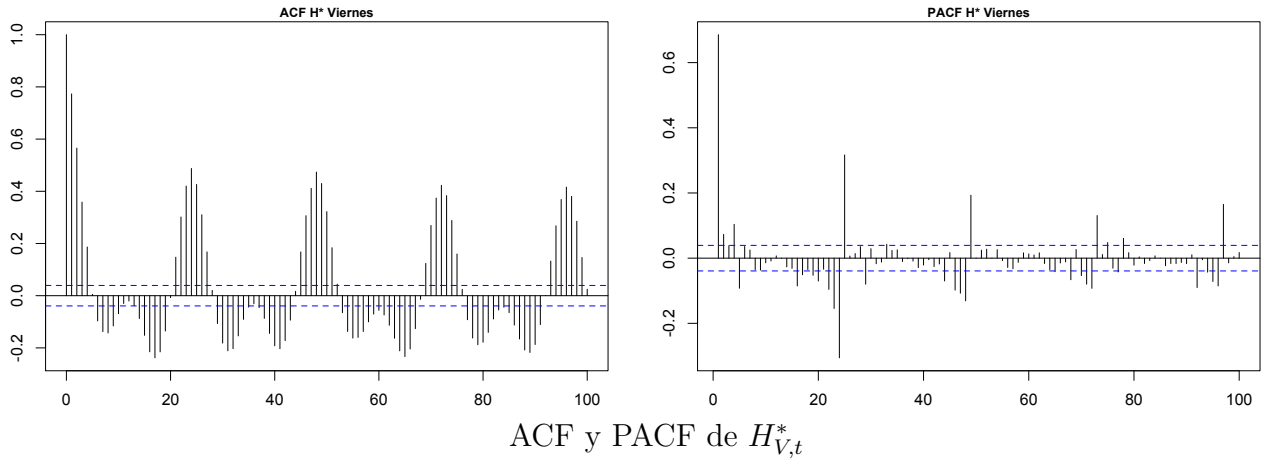
$$H_{i,t}^{**} = H_{i,t}^* - H_{i,t-7}^* \quad (6)$$

Las series parecen ser estacionarias. Lo vamos a comprobar aplicando el test de Dickey-Fuller y Ljung-Box a cada una de ellas:

Resultados	$H_{L,t}^{**}$	$H_{M,t}^{**}$	$H_{X,t}^{**}$	$H_{J,t}^{**}$	$H_{V,t}^{**}$	$H_{S,t}^{**}$	$H_{D,t}^{**}$
DICKEY-FULLER	-18.03	-18.53	-18.21	-15.65	-15.41	-13.42	-13.47
p-value	< 0,01	< 0,01	< 0,01	< 0,01	< 0,01	< 0,01	< 0,01
LJUNG-BOX	-470.15	-485.03	-445.81	-534.78	-546.32	-437.41	-544.08
p-value	< 0,01	< 0,01	< 0,01	< 0,01	< 0,01	< 0,01	< 0,01


Resultados de los tests para las series  $H_{i,t}^{**}$

Se rechaza la hipótesis  $H_0$  de presencia de raíz unitaria y guardamos la hipótesis de estacionaridad para cada una.




### 2.4.3. Modelización

Seguimos con el estudio de los autocorrelogramas y se puede notar que un proceso  $\text{SARIMA}(p, d, q)(P, D, Q)_{24}$  se ajustaría bien a los datos. Vamos a detallar el procedimiento.




Con la presencia de una correlación parcial en  $lag = 1$  asociada al decrecimiento exponencial del ACF, parece pertinente un ajuste a un  $\text{SARIMA}(1, 0, 0)(0, 1, 0)_{24}$ . El resultado de este ajuste se muestra a continuación.




ACF y PACF de los residuos de un SARIMA(1, 0, 0)(0, 1, 0)<sub>24</sub> a  $H_{V,t}^*$

El PACF decrece a lo largo de los múltiplos de 24 cuando el ACF tiene un componente significativo para  $lag = 24$ . Este examen sugiere el ajuste con un SARIMA(1, 0, 0)(0, 1, 1)<sub>24</sub>.



ACF y PACF de los residuos de un SARIMA(1, 0, 0)(0, 1, 1)<sub>24</sub> a  $H_{V,t}^*$

Parece que la mayoría de las dependencias de los datos hayan sido explicadas, salvo por el factor de  $lag = 5$  que contiene aún una fuerte correlación. Vamos a intentar sobreajustar el modelo por un SARIMA(5, 0, 0)(0, 1, 0)<sub>24</sub> y compararlo con el criterio de Akaike.



ACF y PACF de los residuos de un SARIMA(5, 0, 0)(0, 1, 1)<sub>24</sub> a  $H_{V,t}^*$

SARIMA	(1, 0, 0)(0, 1, 1) <sub>24</sub>	(5, 0, 0)(0, 1, 1) <sub>24</sub>
AIC	-3076.85	-3111.62

Comparación por criterio de Akaike



Siguen pequeñas dependencias no explicadas pero esta nueva modelización ha hecho desaparecer el pico que aparecía en el  $lag = 5$ . Ninguna otra dependencia parece ser lo suficientemente importante como para cambiar el modelo, podrían ser debidas a errores en la modelización de  $D_t$  que introduce ahora un error dentro de cada día.

A este nivel de la modelización aumentar los ordenes del modelo no mejoran mi criterio de Akaike. El modelo elegido para representar la serie  $H_{V,t}$  es un SARIMA(5, 0, 0)(0, 1, 0)<sub>24</sub>.

#### 2.4.4. Validación



##### 2.4.4.a. Normalidad

Como se lo podía imaginar, la condición de normalidad de los residuos está rechazada. La distribución está apuntada (aún más que por el caso de la serie  $D_t$ ) y enseña claros signos de exceso de kurtosis y en menor medida, skewness. Los QQ-plot y distribución de densidad de la serie se puede ver en el cuadro a continuación.



QQ-Plot y Densidad estimada de la serie de los residuos de la serie  $H_{V,t}^*$

La agrupación de volatilidad por periodo y el análisis de la repartición del cuadrado de los residuos, permiten identificar claramente un efecto GARCH. El impacto de esta conclusión se analizará más adelante.



Repartición en el tiempo de los Residuos de la serie  $H_{V,t}^*$  y de sus cuadrados


#### 2.4.4.b. Ruido Blanco

Las series pasan el test de Ljung-Box de no autocorrelación. Los resultados están recapitulados en la tabla siguiente:

Serie	SARIMA	$\chi^2$	p-value
$H_{L,t}^{**}$	$(2, 0, 0)(0, 1, 1)_{24}$	826.85	0.417
$H_{M,t}^{**}$	$(7, 0, 0)(1, 1, 1)_{24}$	865.07	0.0546
$H_{X,t}^{**}$	$(6, 0, 0)(1, 1, 1)_{24}$	824.24	0.5498
$H_{J,t}^{**}$	$(3, 0, 0)(1, 1, 1)_{24}$	696.71	0.999
$H_{V,t}^{**}$	$(5, 0, 0)(0, 1, 1)_{24}$	499.82	0.998
$H_{S,t}^{**}$	$(2, 0, 0)(0, 1, 2)_{24}$	630.41	1
$H_{D,t}^{**}$	$(14, 0, 0)(1, 1, 1)_{24}$	870.39	0.16

Resultados del test de LJUNG-BOX para  $K = 830$

## 2.5. Modelización GARCH de los residuos



Hemos puesto en evidencia la presencia de un efecto GARCH en cada una de la series horarias consideradas. No obstante, se revela contra productivo intentar modelizar un efecto GARCH para cada una de las series y eso por la única razón de que estas series no son continuas en el tiempo.

Un efecto GARCH traduce un cambio en la repartición de la volatilidad durante un periodo determinado, y eso para todos los días en este periodo sin discriminación. Entonces, los modelos estando desacoplados, no reflejarían esta unidad en la repartición de sus residuos a la hora de lanzar simulaciones. El carácter aleatorio de la presencia de esos picos de volatilidad haría aparecer en


distintos momentos los picos de volatilidad para cada una de las series. Al reconstruir la serie completa, la repartición de picos sería totalmente incoherente.

Por todas estas razones, sería mucho más lógico volver a recrear la unidad de la serie de los residuos brutos de cada serie e intentar modelizarla mediante un GARCH común. En un siguiente paso, se considera que los residuos de cada serie son las partes constitutivas del modelo de residuo general.

### 2.5.1. Modelización

Se asume que el modelo elegido para la modelización es un GARCH(1,1). El perfil de repartición de densidad estando claramente no gaussiano y más bien apuntado, se ajusta un modelo con una condición de repartición de residuos siguiendo una ley de Student como descrita en la parte 3.

Los residuos después de ajustar el modelo, siguen siendo no *i.i.d* como se nota en la gráfica de abajo. Veremos más tarde como tener en cuenta el carácter no *i.i.d* de la distribuciones por las simulaciones.



Computación: `ugarchspec(variance.model, mean.model, distribution.model, .`

- `variance.model: list(model = "sGARCH", garchOrder = c(1, 1))`

- mean.model: NULL
- distribution.model : “std”




Computación: `ugarchfit(spec, data, out.sample, ...)`

- spec: ugarchspec
- data: data
- out.sample : 0

## 2.6. Modelo Completo

Ahora que el máximo de dependencia ha sido analizado y explicado, se vuelve a construir la curva final con las partes explicadas de los distintos modelos.





Evolución del ajuste del modelo a la serie

### 3. Simulaciones

La idea es generar escenarios que sean posibles mediante la intervención a 3 niveles del modelo. Intervenimos en esos pasos de las simulaciones:

- La tendencia lineal de la serie  $Y_t$
- El residuo de la serie  $D_t$
- El residuo final de las series  $H_{i,t}$

Vamos a analizar como gestionar esta intervención.

#### 3.1. Serie $Y_t$

Hemos visto que la serie  $Y$  se descomponía en una parte estacional y una tendencia. La parte estacional trata de coger la dinámica general de la serie a lo largo del año cuando la tendencia refleja situaciones de mercado (capacidad instalada, demanda etc...). Se puede considerar esta tendencia como el “esqueleto” del modelo: da la dirección general al nivel de la serie. Entonces, aquí se encuentra una “palanca” que impacta de manera durable el nivel de los precios, y entonces la calidad de la simulación. Hay que tener una idea del por qué de este crecimiento. Por eso hay que evaluar si la situación general que hemos observado en los últimos años va a seguir siendo igual, que sea a nivel regulatorio, técnico etc.

A partir de ahí tenemos tres opciones: o se apuesta que la evolución seguirá igual, o pensamos que el fenómeno tiene buena probabilidad de amplificarse o se considera que esta evolución no se justifica más y consideramos un decrecimiento. Esta decisión concierne más un nivel estratégico que estadístico y el impacto puede ser muy importante a la hora de basarse sobre su resultado.

Considerando este aspecto, la estrategia que vamos a adoptar por el lanzamiento de las simulaciones es de considerar que la tendencia es a la baja, hasta llegar a un crecimiento nulo. La razón de esta elección se encuentra en el gráfico 1 : al considerar efectos a largo plazo, se puede ver que estamos ahora más o menos al nivel que tenían los precios antes de la crisis del 2008, la cual destaca inmediatamente. Entonces, vamos a considerar que estuvimos hasta ahora en una fase de transición , debido a un choque y que estamos volviendo a la normalidad. Por esta razón fijamos el factor de crecimiento a 0 para lanzar las simulaciones.




Figura 1: Precio Mensual del spot desde 2007

### 3.2. Bootstrap

La modelización de las series  $D_t$  y de residuo plantea el problema de la no normalidad de los residuos conseguidos. A parte de considerar los problemas de relevancia teórica que engendra, nos pone ante un problema técnico: las simulaciones no van a adoptar un comportamiento que se podría en primera aproximación relacionar con un comportamiento plausible. La aproximación gaussiana tendrá tendencia a aumentar el intervalo inter-cuartil de mi distribución por culpa de la kurtosis de la distribución real. Al considerar que además se trata de pasar de un estudio sobre logaritmos, al volver a la serie “real” se aplicará a esos desvíos generalizados, una ley exponencial que aumentará aún más la discrepancia.

Entonces, para solucionar este problema vamos a utilizar un “bootstrap”. El bootstrap es un método que consiste en utilizar la distribución de referencia que tenemos y en elegir de manera aleatoria una recombinación de ella: conseguimos al final una densidad de distribución igual a la distribución experimental, con valores de residuos plausibles, porque es resultante de mi pasado. En vez de usar para las simulaciones un aleatorio gaussiano para el valor de la “innovación”, es decir del error que se comete al momento de la predicción, uso un valor cogido aleatoriamente en base a mi distribución pasada. Consigo entonces la innovación de mi proceso por bootstrap que tengo que introducir en mi modelo para simulación.

Aplico un método de bootstrap para generar las innovaciones de  $\hat{D}_t$  y del residuo final del modelo GARCH. En el caso de  $\hat{H}_{i,t}$ , hay que distribuir los resultados GARCH conseguidos después del proceso, a cada una de las series  $\hat{H}_{i,t}$  para que sirva a su vez de innovación para la generación de los precios horarios.


### 3.3. Número de simulación

Se simulan por separado por bootstrap las series  $\hat{D}_t$  y  $\hat{H}_{i,t}$ . Para tener un nivel aceptable de escenario, se requiere un número de simulación del orden de 10 000.

Por lo tanto, para ahorrar tiempo de cálculo, se considerará oportuno realizar 500 simulaciones de cada una y generar escenarios “secundarios” que serán una mezcla de los escenarios generados. El objetivo es conseguir con el menor tiempo de cálculo posible, una máxima eficiencia. Así a cada simulación  $\hat{D}_t$  generada, se asocia diez simulaciones seleccionadas al azar dentro de las generadas por  $\hat{H}_{i,t}$ . Y al revés, se actúa de la misma manera para cada simulación  $\hat{H}_{i,t}$  generada. Al final, tenemos 5000 escenarios completos (es decir  $\hat{D}_t$  y  $H$ ) para los dos: conseguimos 10000 escenarios ahorrando tiempo de cálculo. Un umbral de 500 ha sido elegido para asegurar una buena repartición del bootstrap y evitar una redundancia en su generación.


### 3.4. Resultados

Las simulaciones parecen coger de manera satisfactoria la dinámica de los precios reales.



Computación: `ugarchboot(spec, n.ahead, method, ...)`

- spec: `ugarchspec`
- n.ahead: 365\*24
- method: "partial"



Comparación de dinámica para 3 semanas seguidas

Computación  $\hat{H}_{i,t}$ :<sup>1</sup> `mysimulate.Arima(model, nsim, innovation)`

- model: modelo arima  $\hat{H}_{i,t}$


---

<sup>1</sup>Esta función no está implementada en los paquetes de R. Ver anexo para su definición

- nsim: 366\*24/7
- innovation: innovación GARCH  $I_{garch,i}$

Computación  $\hat{D}_t$ : `simulate(model, n, bootstrap)`

- model: modelo arima  $D_t$
- n: 366
- bootstrap: TRUE



Spot 2012 y una Simulación del año 2012 entero

## 4. Cálculo de cobertura

### 4.1. Planteamiento del problema

Cada distribución de precio tiene su punto de equilibrio a la hora de cruzar los datos con el consumo de cliente. En efecto como explicado en la segunda parte, dependiendo del perfil de consumo del cliente, la distribución de los precios que van a corresponder al precio mercado a la hora de comprar o de vender, cambian. Todo depende de si estoy o no por encima del volumen que me he cerrado en el mercado a futuro. Así tiene que haber un cierto volumen que me permite alcanzar el equilibrio entre lo que vendo y lo que compro, y eso por cada producto que constituye mi cobertura. Mi balance está definido por:

$$\mathcal{B}_{Q_i}(V_{cobertura}) = \sum_{j \in Q_i} ((C_j - V_{cobertura}) \hat{P}_j) \quad (7)$$

Donde  $Q_i$  es el periodo de contrato de mi producto trimestral,  $(C_j)$  es el consumo horario del cliente y  $(\hat{P}_j)$  es el precio simulado del mercado al momento  $j$ . A partir de aquí, si llamamos  $V_{\acute{o}ptimo}$  el volumen de equilibrio, tenemos  $\mathcal{B}_{Q_i}(V_{\acute{o}ptimo}) = 0$  y según 7 ,


$$V_{\acute{o}ptimo} = \frac{\sum_{j \in Q_i} (C_j \hat{P}_j)}{\sum_{j \in Q_i} (\hat{P}_j)} \quad (8)$$


Ahora basta aplicar 8 a todas mis simulaciones para conseguir la distribución de repartición de  $V_{\acute{o}ptimo}$

## 4.2. Resultados

A continuación se muestran los resultados para  $Q_1$ . La repartición parece efectuarse por valores cerca de la media de consumo por los varios periodos. Así una buena aproximación de  $V_{\acute{o}ptimo}$  podría ser esta media. Por lo tanto no hay por qué elegirlo, sirve sólo de indicación para fijar una estrategia. Lo único es que me aseguro que estando cerca de mi volumen óptimo más probable, disminuye el riesgo de que mi prima esté lejos de cero, que sea por encima (entonces a desfavor de la empresa) o por debajo (a favor).


Además, considerando una cartera entera de cliente, puedo saber exactamente cuál sería mi cobertura, es decir si tendría que cerrar otro MWh en el mercado para incluir un nuevo cliente o si dejo abierta una parte del consumo y tomo el riesgo de no cubrirlo a  $V_{\acute{o}ptimo}$ . En todos los casos, puedo evaluar cuál sería la prima de riesgo correspondiente por cada estrategia y evaluar el riesgo que tomo. Eso es el siguiente paso que vamos a ver en el siguiente párrafo.






### 4.3. Back-Testing 2012

Tenemos los valores de los dos primeros trimestres de 2012 con los cuales podemos ver lo que hubiera pasado en cuanto a la definición del volumen óptimo:








Podemos ver que  $V_{\text{optimo},2012Q1}$  y  $V_{\text{optimo},2012Q2}$  están dentro del intervalo definido por las simulaciones.

## 5. Determinación de la prima de riesgo


### 5.1. Resultados

Acabamos de ver como fijar el volumen óptimo de cobertura y si se decide cerrar este volumen, entonces la empresa asume menos riesgo con este cliente en particular. Pero al suponer que haya otros clientes, para encajar mejor en la cartera, se puede decidir tomar un riesgo: cerrar un volumen más pequeño que  $V_{\text{optimo}}$  o cerrar un volumen superior. Estando en esa situación, voy a evaluar la repartición del balance  $\mathcal{B}_{Q_i}(V_{\text{cobertura}})$  aplicando 7 y tomar una decisión:



Resultado de las simulaciones de  $\mathcal{B}_{Q3}(V_{cobertura} = 10MWh)$   
dividido por el consumo del periodo

y la densidad de repartición asociada,



Repartición de densidad  $\mathcal{B}_{Q3}(V_{cobertura} = 10MWh)$

Ahora que tenemos la distribución de  $\mathcal{B}_{Q3}(V_{cobertura} = 10MWh)$  podemos decidir el nivel de la prima de riesgo que se va a aplicar al cliente. Si tengo muy pocos clientes, elegir el máximo puede ser una solución. Por lo tanto, hay que tener en cuenta otras consideraciones a la hora de decidir la prima que se lo va a aplicar. Por ejemplo el argumento comercial:


- ¿la oferta es atractiva aplicando esta prima?

- ¿El precio de la competencia está por encima o por debajo del mío?
- ¿Estoy dispuesto a asumir un riesgo más para conseguir el cliente?


Entonces eso depende de cada empresa y de su capacidad para tomar un riesgo por ser competitivo.

## 5.2. Back-Testing 2012

Simulamos en esta parte una estrategia que consiste en cerrar un volumen igual al volumen medio del consumo del cliente. Vamos a ver la repartición de balance correspondiente y enfrentarlo a los resultados para los dos primeros trimestres de 2012.



Repartición de densidad  $\mathcal{B}_{Q1}(V_{cobertura} = \overline{V_{consumo,Q1}})$



Repartición de densidad  $\mathcal{B}_{Q2}(V_{cobertura} = \overline{V_{consumo,Q2}})$

La tabla siguiente recoge los resultados conseguidos:

Periodo	Q1	Q2
$V_{cobertura}$	11.61 MWh	10.49 MWh
95 %	1.14 €/MWh	1.27 €/MWh
Máximo	1.61 €/MWh	1.75 €/MWh
Real	1.55 €/MWh	1.29 €/MWh

Tabla de resultado de  $\mathcal{B}_i$

Otra vez estamos dentro del intervalo de repartición. Si hubiéramos elegido el criterio de cobertura a 95 % hubiéramos perdido 0.02 cts/MWh en Q1 y 0.41 cts/MWh en Q2.

Elegir un volumen de cobertura que sea céntrico dentro de la distribución de  $(V_{optim})$  sería una buena estrategia para intentar que el  $V_{optimo}$  efectivamente realizado sea lo más cercano posible del que he fijado a priori. Desde este punto de vista,  $\overline{V_{consumo}}$  y  $\overline{V_{optimo}}$  se valen.

## 6. Conclusión

### 6.1. La calidad de la previsión

La pertinencia del modelo es la piedra angular del estudio sobre la cual se desarrollan todos los cálculos. De ella depende la calidad

del resultado y de la validez de su uso. Así pues, su análisis es una etapa crítica que necesita un cuidado especial.

Sin embargo, hemos visto que era difícil conseguir la validez de todos los requisitos que nos impone la teoría sobre las hipótesis de partida como sobre los residuos generados por el propio modelo. En particular el carácter gaussiano de los residuos nunca se alcanza. Este ejemplo, que representa un problema sistémico en el mundo de las series financieras, subraya la complejidad de las relaciones que vinculan los precios entre si. Esta complejidad sobrepasa la capacidad de tratamiento del modelo propuesto por el simple hecho de que la modelización se hace al coste de una simplificación de la realidad.

En nuestro método , esta simplificación y sus aproximaciones encuentran sus orígenes en dos niveles principalmente. En primer lugar, el carácter aditivo de la descomposición y la resolución sucesivas de los modelos permiten que los errores se propaguen a lo largo de la cadena de modelización. La evaluación no simultánea del modelo en su conjunto es fuente de aproximación porque no permite mejorar el modelo en su globalidad, enfocándose sobre la mejora de los procesos por separado. En segundo lugar, el propio método de descomposición en serie temporal por proceso SARIMA, de la cual la teoría general permite generar procesos multi-estacionarios, en su forma práctica de computación , permite implicar tan solo un periodo en la evaluación de los efectos estacionarios, cuando los datos, en particular los de la serie intra diaria, enseñan mucha más riqueza interna.

Una última limitación sería el carácter demasiado “ambicioso” del estudio. Por ambicioso se entiende el largo plazo sobre el cual se hace la predicción: un año entero, desglosado a nivel horario. Con este nivel de precisión, el umbral de validez es muy grande. Lo importante ha sido conseguir la mejor previsión posible en un momento dado, aunque realmente no se trata de poder predecir a tan alta frecuencia por periodos tan lejanos. A pesar de esas limitaciones y considerando los resultados conseguidos, el modelo parece lo suficientemente correcto para tratar de trabajar con el.

## 6.2. Críticas

El crecimiento de la herramienta informática y el desarrollo del campo de los estudios en serie temporal, al cual debemos mucho a la industria financiera, han popularizado el hecho de recurrir a este tipo de modelización para poder predecir la evolución de fenómenos

tan distintos como es la serie económica o meteorológica. Ahora bien, los modelos, sean lo sofisticados que sean, integran mal por naturaleza el riesgo operacional y el sector eléctrico es uno de los más arriesgados desde este punto de vista. No únicamente por el carácter no almacenable de esta forma de energía, sino también por la evolución de las tecnologías y de la regulación que acentúan aún más el fenómeno.

¿Se puede limitar su impacto en los modelos? Ahora se hace sentir la limitación, puede ser la más importante, de las series temporales: se basan en la hipótesis muy fuerte de que el modelo elaborado a partir del histórico no está modificado para tiempos futuros. Entonces, la respuesta a esta pregunta no puede ser estadística ni tampoco matemática. Aquí es cuando se necesita el peritaje de sectores transversales que participan en la evolución del mercado, para poder revelar desde otras perspectivas, características que rigen su evolución y proponer unas pautas que servirán de base al desarrollo de un modelo coherente. Los modelos no explican todo, y sobretodo no son eficientes si no están guiados.

### **6.3. Perspectivas de futuras mejoras**

El modelo ha dado mucha importancia al desarrollo de los procesos SARIMA para rendir cuenta del carácter estacional de la serie. Debido a eso, la modelización GARCH ha sido básica y compensada por parte por el uso de la técnica de bootstrap para las simulaciones.

Sería una mejora innegable al modelo actual investigar más en detalle la serie de los residuos finales y ajustarle un modelo más adaptado. También se ha notado el problema de modelización intradiaria. Una solución podría ser el desarrollar un modelo específico por hora, o por grupos de horas compartiendo unos rasgos comunes. Otra perspectiva que podría ser de interés sería relacionar el modelo a otra variable externa sobre la cual el modelo se podría basar para mejorar su previsión. Se conoce en la literatura bajo el nombre de regresión externa, y muchos estudios consiguen resultados concluyentes relacionando así el precio con sus fundamentos a través de, por ejemplo, series de nivel de insolación, demanda, precipitación, temperatura etc.

### **6.4. Conclusión**

El proyecto consigue ofrecer un método para fijar las primas de riesgo asociadas a la variación de los precios de mercado. Este

método se basa sobre la definición de un modelo y de sus simulaciones. El objetivo de esas simulaciones es crear un abanico de futuros posibles, lo suficiente amplio para llevar a cabo un estudio estadístico, que tiene por fin crear una distribución, si no de todos, del número más grande, de los sobrecostos posibles que puede generar el consumo de un cliente en particular cuando se acopla con variaciones de alta volatilidad de mercado.

Permite sentar las bases de una estrategia de cobertura y de limitación de riesgo a adoptar para minimizar el nivel de dicha prima.

La fijación de la prima en si misma se hace en un último paso dentro de una reflexión más grande, sobre los niveles de riesgo juzgados aceptables para la empresa.

Es una herramienta que ofrece una flexibilidad y una interacción amplia al considerar el beneficio de la integración del cliente a la cartera existente y al evaluar el impacto financiero de dicha decisión.

## Parte V

# Conclusión

En esta parte se recogen las conclusiones obtenidas tras el diseño de un método para fijar las primas de riesgos asociadas a ofertas a precio fijo para clientes industriales, durante el periodo de practica en la comercializadora de GDF-Suez en España y la elaboración de este documento.

### 1. Objetivos del proyecto

El presente proyecto de fin de carrera tenía por objeto un análisis y una reflexión sobre la fijación de prima para un producto complejo que es la oferta a precio fijo. A lo largo de este trabajo hemos presentado el funcionamiento del mercado, los diferentes productos que se ofrecen a los clientes para suministrarles electricidad y la problemática de la fijación de los precios. Luego, hemos introducido teorías matemáticas y hemos diseñado un método de cálculo que permite:

- Definir una estrategia de cobertura frente al mercado para la empresa.
- Definir una estrategia de fijación de prima
- Ayudar al departamento Marketing para su toma de decisión.
- Calcular las primas a añadir al cliente
- Medir la incertidumbre relacionada con esta prima.
- Ser reactivo ante una consulta de una oferta

Obviamente, la mayor parte de los objetivos del proyecto están cumplidos y ahora, tenemos una herramienta que permite proponer precios atractivos para los clientes y posicionarse con respecto a la competencia. Un objetivo de más ha sido la disminución en el plazo de entrega de la oferta en más de un 90 %, al mismo tiempo que una mejora del método de cálculo.



## 2. Objetivos personales

La realización de este proyecto me ha permitido alcanzar y satisfacer plenamente mis objetivos personales. En primer lugar destacar que en todos los sentidos la experiencia ha resultado muy positiva, no sólo por los nuevos conocimientos adquiridos sino también por lo que este trabajo ha supuesto a nivel personal y profesional.

En este sentido, la participación activa en el desarrollo del proyecto, con todo lo que supone de concertación, intercambios y formación, en el departamento de Pricing de GDF-Suez España , ha revelado ser una experiencia muy enriquecedora. Aunque el proyecto no haya sido la actividad más importante de las tareas que he llevado en el seno de la empresa, ha sido una fuente de satisfacción innegable. Gracias a él, he adquirido una experiencia profesional de calidad dado que su realización ha supuesto la adquisición de habilidades en varios campos, dentro de los cual los más relevantes son:

- Creación de una herramienta de tratamiento de curva de carga de cliente, automatizando el tratamiento y la generación de previsiones de consumo futuro.
- Creación de una herramienta de generación automática de presentación a destino de los comerciales y de su actualización, también automatizada.
- Estudio de correlación entre los mercados francés y español a través del estudio de los flujos de la interconexión entre esos países.

## Referencias

- [1] Koopman S.J., Carnero M.A., Ooms M. (2005). Periodic Seasonal Reg-ARFIMA-GARCH Models for Daily Electricity Spot Prices. In *Tinbergen Institute Discussion Paper*.
- [2] Charpentier, A. (2005). Séries Temporelles: Théorie et applications. In *Université Paris-Dauphine*.
- [3] Robert CP, Casella G. (2009). Introducing Monte Carlo Methods with R. In *First Edition, Springer*.
- [4] Shumway R.H., Stoffer D.S.. Time Series Analysis and Its Applications with R In *3rd Edition, Springer*.
- [5] Duclert Site especializado en R In <http://www.duclert.org/Aide-memoire-R/Graphiques>.
- [6] Paradis E. R pour les débutants (2005) In [cran.r-project.org/doc/contrib](http://cran.r-project.org/doc/contrib).
- [7] Furio D., Meneu V (2009). Analysis of the forward risk premium in the spanish electricity market. In *Instituto Valenciano de investigacion economica*.
- [8] Conejo A., Plazas M., Molina A. (2005) Day ahead electricity price forecasting using wavelet transform and ARIMA Models. In *Transaction on power system, vol.20*.
- [9] Cartea A., Villaplana P. (2007) Spot price modeling and the valuation of electricity forward contract: the role of demand and capacity. In *CNE*.
- [10] Prenat M. (2010) Serie chronologiques: Vol1 In *Université 1 Paris-Sud*.
- [11] Chatfield, C. (2004) The Analysis of Time Series: An Introduction In *Chapman Hall/CRC*.
- [12] Misiorek, A. (2004) Forecasting spot electricity prices with time series models In *The European Electricity Market EEM-05*.
- [13] Duffie, D. (1988) Security Market: Stochastic Market In *Boston Academic Press*.

- [14] Adèr, H. J., Mellenbergh G. J., Hand, D. J. (2008). Advising on research methods: A consultant's companion. In *Huizen, The Netherlands: Johannes van Kessel Publishing. ISBN 978-90-79418-01-5*

## Appendix A: Anexo

`mysimulate.Arima` se basa sobre el código de la función `simulate` del paquete `forecast` de R. Consiste en introducir la innovación, que se calcula previamente a parte, en vez de usar el método de bootstrap que está facilitado.

```
1
2
3 mysimulate.Arima <- function(object, nsim=length(object$x),
4                               seed=NULL, xreg=NULL, future=TRUE, bootstrap=FALSE,
5                               innovation1=NULL, ...)
6 {
7   #Error check:
8   if(object$arma[7] < 0)
9   {
10    stop("Value for seasonal difference is < 0. Must be >= 0")
11  }
12  else if((sum(object$arma[c(3,4,7)])>0) && (object$arma[5] <
13    2))
14  {
15    stop("Invalid value for seasonal period")
16  }
17
18  #####
19  #Random Seed Code
20  if (!exists("Random.seed", envir = .GlobalEnv))
21  runif(1)
22  if (is.null(seed))
23  RNGstate <- .Random.seed
24  else
25  {
26    R.seed <- .Random.seed
27    set.seed(seed)
28    RNGstate <- structure(seed, kind = as.list(RNGkind()))
29    on.exit(assign("Random.seed", R.seed, envir = .GlobalEnv))
30  }
31  #####End Random seed code
```

```

1
2  #Check for seasonal ARMA components and set flag accordingly.
   This will be used later in myarima.sim()
3  if(sum(object$arima[c(3,4)])>0)
4  {
5    flag.s.arima <- TRUE
6  }
7  else
8  {
9    flag.s.arima <- FALSE
10 }
11
12 #include <iostream.h>
13 #Check for Seasonality in ARIMA model
14 if(sum(object$arima[c(3,4,7)])>0)
15 {
16   #return(simulateSeasonalArima(object, nsim=nsim, seed=seed, xreg=
      xreg, future=future, bootstrap=bootstrap, ...) )
17   if(sum(object$model$phi) == 0)
18   {
19     ar <- NULL
20   }
21   else
22   {
23     ar <- as.double(object$model$phi)
24   }
25   if(sum(object$model$theta) == 0)
26   {
27     ma <- NULL
28   }
29   else
30   {
31     ma <- as.double(object$model$theta)
32   }
33   order <- c(length(ar),object$arima[6],length(ma))
34
35   if(future)
36   {
37     model <- list(order=order, ar=ar, ma=ma,sd=sqrt(object$
      sigma2),residuals=residuals(object), seasonal.
      difference=object$arima[7], seasonal.period=object$arima
      [5], flag.seasonal.arima=flag.s.arima, seasonal.order=
      object$arima[c(3,7,4)])
38   }

```

```

1 else
2 {
3 model <- list(order=order, ar=ar, ma=ma, sd=sqrt(object$
      sigma2), residuals=residuals(object))
4 }
5
6 if(object$ar[7] > 0)
7 {
8 flag.seasonal.diff <- TRUE
9 }
10 else
11 {
12 flag.seasonal.diff <- FALSE
13 }
14
15 }
16 else
17 {
18 ####Non-Seasonal ARIMA specific code: Set up the model
19 order <- object$ar[c(1, 6, 2)]
20 if(order[1]>0)
21 ar <- object$model$phi[1:order[1]]
22 else
23 ar <- NULL
24 if(order[3]>0)
25 ma <- object$model$theta[1:order[3]]
26 else
27 ma <- NULL
28 if(object$ar[2] != length(ma))
29 stop("MA length wrong")
30 else if(object$ar[1] != length(ar))
31 stop("AR length wrong")
32
33 if(future)
34 {
35 model <- list(order=object$ar[c(1, 6, 2)], ar=ar, ma=ma, sd=
      sqrt(object$sigma2), residuals=residuals(object),
      seasonal.difference=0, flag.seasonal.arma=flag.s.arma,
      seasonal.order=c(0,0,0), seasonal.period=1)
36 }

```

```

1 else
2 {
3   model <- list(order=object$arma[c(1, 6, 2)],ar=ar,ma=ma,sd=
4     sqrt(object$sigma2),residuals=residuals(object))
5 }
6 flag.seasonal.diff <- FALSE
7 ###End non-seasonal ARIMA specific code
8 }
9
10
11
12 if (is.element("x", names(object)))
13   x <- object$x
14 else
15   x <- object$x <- eval.parent(parse(text = object$series))
16
17 if(is.null(tsp(x)))
18   x <- ts(x,f=1,s=1)
19
20 n <- length(x)
21 d <- order[2]
22 if(bootstrap)
23   e <- sample(model$residuals,nsim+d,replace=TRUE)
24 else
25   e <- innovation1
26
27
28 use.drift <- is.element("drift", names(object$coef))
29 usexreg <- (!is.null(xreg) | use.drift)
30 if (!is.null(xreg))
31 {
32   xreg <- as.matrix(xreg)
33   if(nrow(xreg) < nsim)
34     stop("Not enough rows in xreg")
35   else
36     xreg <- xreg[1:nsim,]
37 }

```

```

1  if (use.drift)
2  {
3    dft <- as.matrix(1:nsim) + n
4    xreg <- cbind(xreg, dft)
5  }
6
7  narma <- sum(object$arima[1L:4L])
8  if(length(object$coef) > narma)
9  {
10   if (names(object$coef)[narma + 1L] == "intercept")
11   {
12     xreg <- cbind(intercept = rep(1, nsim), xreg)
13     object$xreg <- cbind(intercept = rep(1, n), object$xreg)
14   }
15   if(!is.null(xreg))
16   {
17     xm <- if (narma == 0)
18     drop(as.matrix(xreg) %*% object$coef)
19     else
20     drop(as.matrix(xreg) %*% object$coef[-(1L:narma)])
21     oldxm <- if(narma == 0)
22     drop(as.matrix(object$xreg) %*% object$coef)
23     else
24     drop(as.matrix(object$xreg) %*% object$coef[-(1L:narma)])
25   }
26 }
27
28
29 else
30 {
31   xm <- oldxm <- 0
32 }
33 if(future)
34 {
35   sim <- myarima.sim(model,nsim,x=oldxm,e=e) + xm
36 }
37 else
38 {

```



```

1  if(flag.seasonal.diff)
2  {
3    zeros <- object$arma[5]*object$arma[7]
4    sim <- arima.sim(model,nsim,innov=e)
5    sim <- diffinv(sim, lag=object$arma[5], differences=object$
      arma[7])[-(1:zeros)]
6    sim <- sim + xm
7  }
8  else
9  {
10   sim <- arima.sim(model,nsim,innov=e) + xm
11 }
12 }
13 if(!is.null(object$lambda))
14   sim <- InvBoxCox(sim,object$lambda)
15 return(sim)
16 }
17 }

```